深度学习在工业故障诊断中的应用综述

卢紫阳

摘要：（本文是在学完《深度学习课程》后，对深度学习有一定了解后写的一篇深度学习结合故障诊断应用的的一篇综述，如有不足之处请老师批评指正）。近年来工业过程向过程复杂化、规模大型化的方向发展，传统的故障诊断技术已在解决实际工业过程问题时，遇到了一系列难题。随着深度学习(deep learning)在特征提取与模式识别上的优异性能和独特潜力，深度学习技术被用于故障诊断已经成为当前研究的重点。为此本文介绍了几种典型的基于深度学习的故障诊断方法。最后对于深度学习在故障诊断应用中存在的障碍进行了探讨，并对展望了未来的相关研究方向。

关键字： 深度学习；故障诊断；工业过程

Abstract: In recent years, the industrial process has been developing towards complexity and large-scale, which has posed a series of challenges for traditional fault diagnosis techniques to solve practical industrial process problems. With the superior performance and unique potential of deep learning in feature extraction and pattern recognition, the application of deep learning technology to fault diagnosis has become a current research focus. Therefore, this article introduces several typical fault diagnosis methods based on deep learning. Finally, the obstacles in the application of deep learning to fault diagnosis are discussed, and the future research directions are prospected.

Keywords: Deep Learning; Fault Diagnos; Industrial Processes

0 前言

随着计算机技术、通信技术和传感技术的飞速发展，现代工业过程呈现复杂化、集成化、规模化的新发展趋势，系统过程数据呈现海量化，低价值化，不平衡化的发展趋势。传统的基于数据驱动的故障诊断方法不适应这种新的数据类型。同时工业过程的集成化，也造成了工作单元之间的相互耦合，在成系统呈现出了非线性特性和不确定性。传统的建模方法无法有效处理这种复杂情况。

一般来说，故障指的是是系统中单个变量或者多个变量发生既定轨迹的偏离，进而给产品质量或者系统性能带来严重影响。故障检测与诊断技术就是对过程数据进行监控，来判定系统是否发生故障，同时这对故障发生的位置和种类进行定位和区分。然而，现代工业过程的复杂性和大规模集成化，许多组件之间存在复杂的依赖关系，使得过程数据呈现非线性、不确定性关系。传统的针对单个组件和单元的故障诊断方法难以提取和利用这种非线性关系，因此它的误诊率和漏报率都很大。

近年来， 深度学习在学术界和工业界发展迅猛，在很多传统的识别任务上显著地提高了识别准确率，彰显了其高超的处理复杂识别任务的能力，吸引了大批专家学者对其理论与应用展开研究[1]。当前很多学

者都开始尝试应用深度学习理论来解决各自领域的问题。

深度学习是以神经网络为基础发展起来的一种网络模型，它的特点是网络中包含多个隐藏层。相比较于一般的神经网络模型，深度学习中的深度指的是网络学习得到的非线性运算组合水平的数量，也就是网络隐含层的数量。深度学习拥有更多的隐含层数，因此拥有更好的逼近复杂函数的能力，在面对非线性数据时具有更好的特征提取能力。

深度学习经过多年的发展，已经取得了很多成就，在复杂函数的表达地方面有着无可比拟的优势。本文在总结近几年来国内外深度学习在故障诊断上的应用的基础上，探讨了现代复杂工业过程故障诊断中新的问题和挑战，展望基于深度学习的故障诊断方法在未来的发展前景。

1 深度学习在故障诊断的研究

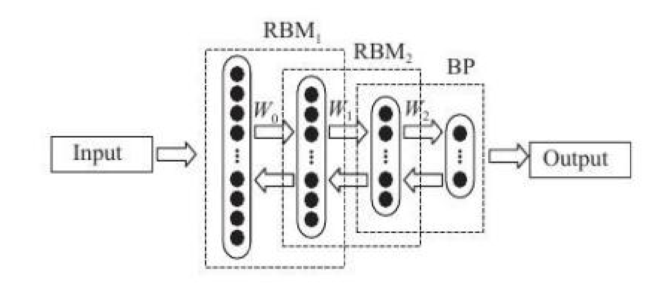
深度学习的主要作用就是提取数据间的有效特征，发现是举荐的内在结构和本质关系。数据的表示方法对于模型的最终效果至关重要。好的数据表示方法能够保留数据中心与任务相关的信息，消除掉不必要的干扰和噪声，从而提高模型的性能。

近几年来，得到广泛应用的几种模型包括深度置信网络（DBN），堆栈自编码器（SAE），卷积神经网络（CNN），递归神经网络（RNN）。为了更加清楚地阐述深度学习在故障诊断中的应用，本文介绍了基于上面四种方法的故障诊断技术的原理和方法，以及相关研究。但是基于 DBN 的故障诊断方面的研究还比较少。

1.1 深度置信网络在故障诊断中的应用

DBN 是一种经典的深度学习模型，它可以通过多层玻尔兹曼机逐层的提取出数据的特征信息，最终形成更加抽象的高层表示。这种方法模拟了人类大脑的神经连接，在训练数据集有限的情况下能提取出数据的本质特征[2]。

DBN 是有多个玻尔兹曼机（RBM）组合而成的深度神经网络模型，如图一是 DBN 的结构模型。



图一：DBN 的模型结构

DBN 的训练方法采用了贪婪预训练方法，首先使用无监督学习算法逐层的训练网络，挖掘数据中的特征信息，然后连接相应的分类器通过监督学习的方式实现对网络中参数的微调，来优化 DBN 网络对于故障分类的能力。其关键的特征提取能力的实现是通过无监督的逐层训练实现的，在逐层的信息传递过程中，原始的信息得到了抽象的特征表示。

基于 DBN 的特征提取技术与传统的人工特征提取技术相比，减少了由于人为操作的不确定性，使得故障诊断过程智能化。此外基于 DBN 的特征提取技术摆脱了传统方法需要对数据进行大量信号处理和经验筛选的依赖，实现故障特征提取的智能化。最后是其具有处理高维度非线性数据的能力，可以有效避免模型诊断能力不足的问题[3]。基于上述的优点，DBN 模型非常适应于目前新时期工业“大数据”的故障诊断难题[4]。

目前 DBN 模型在信号处理方面和得到了广泛的应用，在语音和音频方面基于 DBN 的语音识别技术 DBN-HMM 模型实现了具有竞争力的手机识别精度，卷积 DBN，它已应用于音频和语音数据，用于许多任务，包括音乐艺术家和流派分类、说话人识别、说话人性别分类和电话分类，并取得了很好的结果，其在图像和视频、语言处理和信息检索方面也得到了广泛的应用。

Shao 等[5]、Wang 等[6] 和 Chen 等[7] 均采用 DBN 实现了滚动轴承和齿轮箱的故障诊断，并与现有一些主流故障诊断算法进行了比较，验证了所提出方法实现故障诊断的鲁棒性和精确性。随后，Li 等[8] 紧跟前人的研究，继续在基于 DBN 实现高维数据的异常检测与识别、滚动轴承故障诊断、齿轮箱深度故障特征提取与识别以及高背景噪声信息提取与融合等领域展开研究，均取得了传统方法无法比拟的效果与优势。Lei 等[9]人提出了一种基于注意力机制多尺度 DBN 模型，进一步提升了 DBN 模型在轴承故障中的有效性。Wang 等[10]人为了提高 DBN 模型的故障分类能力提出了一种扩展深度置信网络（EDBN）来充分利用原始数据中的有用信息。将其应用于田纳西州伊士曼（TE）过程进行故障分类，结果

表明，EDBN 比传统 DBN 具有更好的特征提取和故障分类性能。Wei 等[11]提出一种基于 DBN-dropout 的非线性过程故障诊断与辨识方法，减少 DBN 模型过拟合，提高模型的泛化能力。Tian 等[12] 针对在使用深度神经网络的高维数据识别中，经常会遇到数据不足和数据缺失、测量噪声、冗余变量、数据耦合度高等问题提出了一种基于特征的 DBN 方法在 TE 过程中的应用表明，与传统的故障识别算法相比，该方案在识别化学过程异常情况方面具有快速收敛和高精度。随着 DBN 模型的发展，其应用领域从感器健康诊断到压缩机、齿轮箱、滚动轴承等越来越宽泛，但是在过程故障诊断中的研究较少，在这个方面具有较大的研究空间。

基于 DBN 的故障诊断方法可以大致分为以下几个步骤：

（1） 通过传感器获取系统的过程数据，并对数据进行归一化、降噪等预处理过程。

（2） 将采集到的信号进行分批次划分，并且分为训练集数据和测试集数据

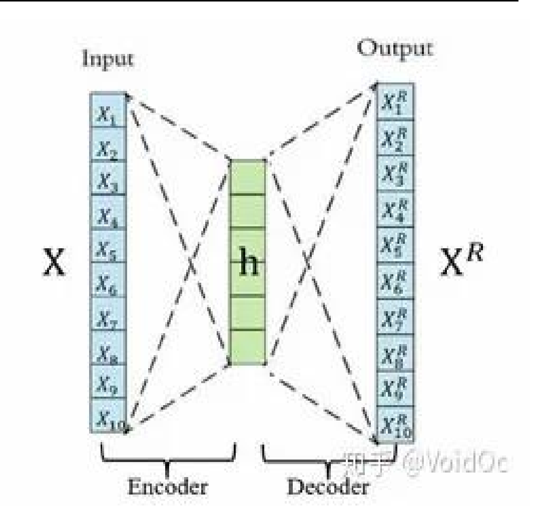
（3） 根据输入信号的形式确定 DBN 模型的输入节点个数，然后建立一个多隐层的 DBN 模型。

（4） 通过贪婪预训练方法逐层对网络参数进行调整，然后接入对应的分类器对网络参数进行微调。

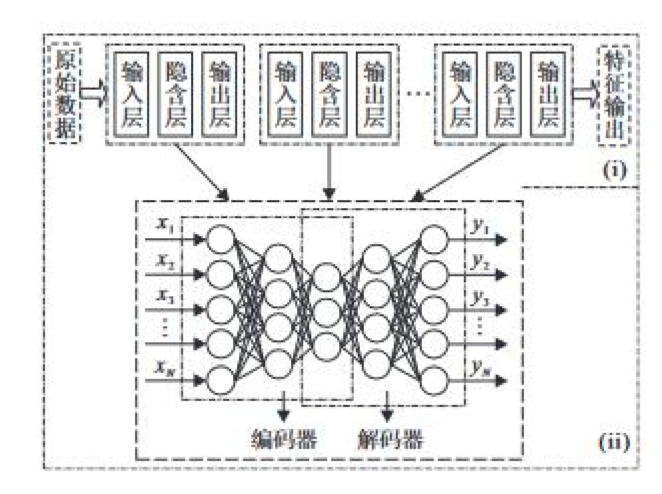
（5） 最后通过测试集数据验证网络的有效性。

1.2 堆栈自编码器在故障诊断中的应用

堆栈自编码器（SAE）能有效提取出原始数据的特征，它是由多个自编码器（AE）堆叠而成的一种深度学习模型。自编码器包括编码器和解码器，如图二所示。其目的是通过寻找一组最优的参数（W，b）使得编码解码后的输出 y 尽可能的重构输入 x。堆栈自编码器就是将多个自编码器的编码器串联起来，组成的深度学习模型，如图三所示。



图二：自编码器结构



图三：堆栈自编码器结构[4]

$$\arg\min_{W,b} L(W,b) = \left[\frac{1}{m}\sum_{i=1}^{m}\frac{1}{2}\|y^{(i)}-x^{(i)}\|^2\right] + \frac{\lambda}{2}\sum_{l=1}^{n_l-1}\sum_{i=1}^{s_l}\sum_{j=1}^{s_{l+1}}\left(W_{ji}^{(l)}\right)^2 \quad (1)$$

其中W,b是网络中的权重系数和偏置，m代表了样本个数，n_l代表了自编码器的层数，s_l代表了第l层的节点个数。式子(1)的第一项叫做重构损失项，用于强化模型的特征提取能力；式子的第二项叫做权值衰减约束项，用于增强自编码器的鲁棒性。

自编码器模型的训练仍然采用梯度下降法进行，是目标损失函数达到最小化。SAE 的训练同 DBN 网络一样，

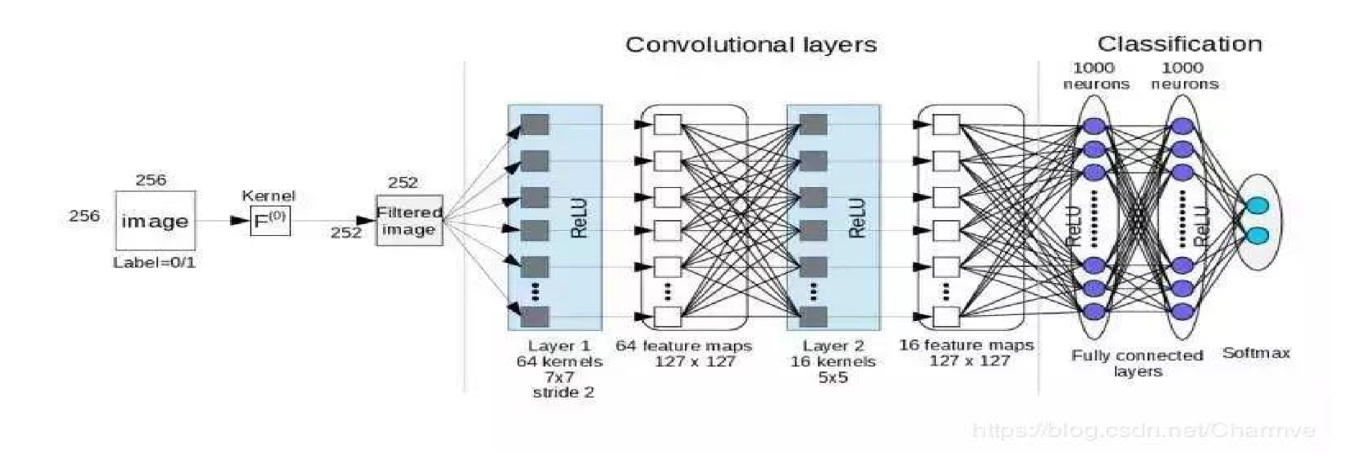
采用贪婪预训练法进行模型的训练。在预训练阶段，单独训练每一个 AE 模型。当低层的模型单独训练好之后，其编码器的输出作为下一层 AE 模型的输入，然后单独训练下一层编码器。各层 AE 模型训练好以后，仅将 AE 模型的编码其部分保留起来串联形成堆栈自编码器的预模型。在全局微调阶段，以数据的标签作为监督信号计算网络的误差，并根据反向传播算法减小误差来调节预训练模型中的参数。堆叠自动编 SAE 是将若干 AE 级联构建多层神经网络,其输出可看作是输入数据经过多次降维后的特征表示[13]

近年来，SAE 算法因为其优异的特征提取能力得到了越来越多的专家学者的关注。邱等[14]人提出了提出一种将层叠 SAE 和分簇协议相结合的数据融合算法 SAEMDA，该将同类特征融合并发送给汇聚节点。仿真实验表明:和 BPFDA,SOFMDA 算法相比,SAEMDA 在网络能耗大致相当的情况下能将数据融合正确率提高 7.5%。Demethual 等[15]针对传统的多目标方法无法解决的具有独特非线性问题的原料处理系统，基于量测信号进行故障诊断，提出了采用扩散图 (DM)、局部线性嵌入 (LLE)和 AE 等相结合的特征提取算法，采用 gustafson kessel 和 k-medoids 算法对编码信号进行分类. 结果表明，此方法实现的故障诊断准确率比传统方法提高了 90 %。张[16]针对传统故障诊断方法依赖特征设计和专家经验的问题,提出一种基于改进的堆栈稀疏自编码器的轴承故障诊断方法，使用训练集对构建的 BAS 优化堆栈稀疏自编码器(BAS-SSAE)的模型进行训练,并通过测试集验证模型的故障诊断分类能力;然后采用 t-分布邻域嵌入算法(t-SNE)表明构建的模型能够对原始数据进行特征优化,挖掘出更具有辨识能力的特征;最后将 BAS-SSAE 模型与随机参数 SSAE 模型、SAE 模型、K 最近邻(KNN)、支持向量机(SVM)进行对比,结果表明该方法在滚动轴承故障诊断方面更具优越性。Sun[17]则展示了利用基于深度神经网络方法的稀疏自编码算法实现异步电机故障分类问题,其采用具有无监督特征提取优势的稀疏自编码模型来学习故障特征,在降噪编码的作用下有效地提出了特征提取的干扰项,提高了特征表示的鲁棒性, SAE 提取特征后将其用于训练神经网络来识别异步电机故障,实验表明,该方法展现了基于深度学习的故障诊断在异步电机故障诊断中所具有的独特优势。陈等[18]提出了一种基于堆栈稀疏自编码器(SSAE)和 softmax 分类器相结合的齿轮故障诊断方法，通过实验结果表明,和文中其他浅层学习模型相比,SSAE 能够从齿轮振动信号中有效学习到所需的深层本质特征,拥有更高的识别准确率,因而证实了该方法优越性。SAE 算法还在机器人、变压器、风力发电机组设备、核电站等方面的故障诊断取得了非常不错的应用。

SAE 算法由于良好的特征提取能力，在故障诊断领域一直被用与实现数据的特征提取和故障分类。并且 SAE 器编码器和解码器均具有良好的特征提取能力和分类能力，因此数据在经过 SAE 算法特征提取后经过简单的分类算法就能得到不错的诊断效果。

1.3 卷积神经网络在故障诊断中的应用

卷积神经网络模型（CNN）是一个非常经典的前馈神经网络，在图像处理上得到了非常广泛的应用。CNN 的每一层都包含多个卷积核，也叫做滤波器。通过这些卷积核对输入信号逐层卷积和池化得到数据的抽象表示。由于 CNN 采用卷积核进行前向传播，减小了模型的参数量，非常适合海量数据的处理和学习。



图四：卷积神经网络结构

卷积神经网络的结构如图四所示，前一部分的卷积层是由卷积操作和子采样操作交替进行的，后一部分的分类层是由普通的多层神经网络构成。卷积操作是通过卷积核对原始图像进行卷积，从而提取原始信号的某些

特征。子采样层是对卷积后的信号进行缩放映射，以减少网络的复杂性，避免过拟合的风险。最后的多层全连接神经网络一般用于分类，而采用 softmax 函数。

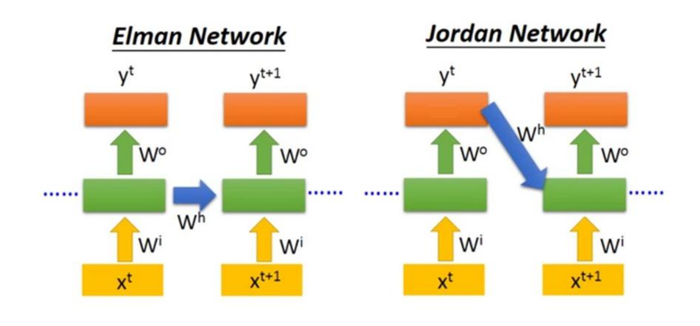
CNN 算法与前面的 DBN 算法和 SAE 算法不它是一种监督学习算法，同时由于采用卷积核对数据进行处理，这种方法降低了网络复杂性减少了 CNN 学习时的难度，因此模型的训练更加简单。CNN 的训练仍然采用梯度下降法对模型参数进行调整。CNN 可提取输入数据的局部特征，并逐层组合抽象生成高层特征,可有效实现故障诊断与识别[19].

张等[20]针对深度卷积神经网络激活过程存在正负值计算不匹配以及信息流通效率低导致的参数冗余问题提出了一种强化深度卷积神经网络模型。这种方法引入一种基于最大平滑单元（Maximum Smoothing Unit，MSF）函数的新激活机制克服传统激活函数的缺点，并且引入注意力机制（Attention mechanism）结合门控循环单元（Gated recurrent unit， GRU）提升 DCNN 的信息流通效率克服参数冗余问题，以综合提升传统 DCNN 模型的故障诊断性能。强化深度卷积神经网络（EDCNN）的现有模型表现出显着提高的性能，这在工业致动器控制系统和工业酸性气体吸收过程这两个过程中的应用得到了验证。Chen 等[21]提出了提出了一种用于齿轮箱故障识别和分类的深度学习算法 CNN 的实现。与同行算法相比，该方法在齿轮箱故障诊断中表现出最佳性能。闫等[22] 针对部分齿轮的运行环境复杂，导致采集的样本数据不够的问题，提出了一种基于 Transformer 和卷积神经网络（CNN）的迁移学习齿轮故障诊断方法。与其他不含 Transformer 的卷积神经网络、多尺度卷积神经网络和二维卷积神经网络相比，Transformer-CNN 的齿轮故障诊断平均准确率更高，其平均准确率可达到 99.64%。

基于 CNN 的故障诊断方法经过近十年的发展已经有了很大的突破和创新。目前基于 CNN 的故障诊断技术常常与注意力机制相结合。

1.4 递归神经网络在故障诊断中的应用

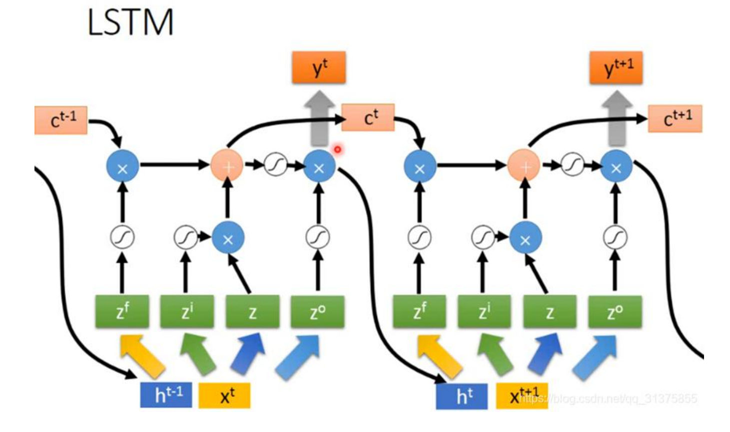
递归神经网络（RNN）既有内部反馈也有前向反馈，其内部反馈可以传递前项节点的状态信息为网络提供了记忆方式，网络的输出不再仅限于当前状态的输入，且与网络之前的内部状态有关。RNN 网络的结构图如图五所示



图五：循环神经网络结构图

RNN 分为 Jordan 型和 Elman 型两种结构，在 Elman 型 RNN 中存在一个关联层，其作用是将前一个时刻的隐藏状态与这一时刻的输入相结合，作为隐层输入。Jordan 模型由于是输出反馈，包含的信息较少因此它表示的动态能力比 Elman 模型较弱。

当输入输出的序列过长时，RNN 模型不能很好保留与当前节点较远出的信息，并且存在梯度消失等问题。针对这一问题，提出了 RNN 的改进算法长短时记忆网络（LSTM），成为目前在故障诊断中应用的主要模型。



图六：长短时记忆网络结构图

长短时记忆网络包含遗忘门、记忆门、输出门，z^f 是h^{t-1}和x^t 的一个对应于遗忘门的整和向量。遗忘门的作用是对神经元的隐藏态C^{t-1}中过时的信息进行清理。z^i 和 z 是记忆门对应的整合向量，记忆门的作用是在C^{t-1}的隐藏状态中添加当前时刻的状态信息将C^{t-1}更新为C^t。z^o 是输出门对应的整合向量，输出门的作用是结合C^t 得到模型的输出y^t 和h^t。

RNN 以及 LSTM 算法与 DBN，SAE，CNN 算法的不同之处在于 RNN 的隐含层之间的连接，使得网络能够

利用样本间的关联信息。因此 RNN 非常适用于处理时序数据或者前后相关联的数据。

Talebi 等[23] 则针对在非线性系统的状态和传感器均不确定或含 有干扰的情况下,采用两种 RNN 实现了系统未知传 感器或执行器故障的检测与隔离,并将其应用在低 轨道地球卫星上,大量仿真实验验证了该方法的有效 性与稳定性。Shao 等[24]提出了用于化学过程故障诊断的多通道 LSTM-CNN 方法，田纳西州伊士曼（TE）的化学过程用于实验分析，并将 MCLSTM-CNN 模型与 LSTM-CNN，LSTM，CNN，RF 和 KPCA + SVM 模型进行了比较。实验结果表明，MCLSTM-CNN 模型具有较高的诊断精度，故障分类结果优于其他模型。Mahmoud[25]提出了一种用于入侵检测的机器学习方法 AE-LSTM，这种模型在检测方法（Dos、Probe、R2L、U2R、Normal）中取得了比其他方法最高的准确度。Zheng 等[26]提出了基于堆叠自编码器的化学过程故障诊断新型无监督数据挖掘方法，该方法主要包括卷积堆叠自编码器特征提取、t 分布式随机邻域嵌入（t-SNE）算法特征可视化和聚类三个步骤，实验结果说明了数据挖掘方法的有效性。

递归神经网络由于能利用输入样本间的信息，因此在预测方面具有不可比拟的优势，在如今的大模型时代 RNN 在深度学习中受到越来越多的重视，它在工业过程的故障诊断中建辉发挥越来越重要的作用。

2. 深度学习在故障诊断应用的障碍

如今随着工业对象的大型化、复杂化，通过机理分析获取监测对象准确的、完备的故障知识已经变得越来越困难。基于深度学习的故障诊断技术通过建立深层的神经网络，模拟人脑的工作原理对大量的过程数据进行学习、理解、分析，并根据输入数据对网络权重进行调整，最终使网络能够获得解读过程数据故障信息的能力。因此基于深度学习的故障诊断的关键在于能否彻底提取过程数据的知识信息。

2.1 大型复杂工业过程的特性

大型的工业系统由于其功能单元很多，而且每一个功能单元都与其他单元有着复杂的内部联系，使得工业系统呈现出特定的特性。

（1） 海量数据特性：随着传感技术和存储技术的发展，大型工业系统都配备了大量的传感器，在空间尺度上拓展了数据量值。从时间尺度上讲工业系统的过程数据在不断产生和储存累积，这也造成了复杂工业过程的海量数据特性。

（2） 复杂性：大型工业过程数据具有很强的耦合行和非线性，此外一些故障早期往往具有很微弱的动态响应一般难以检测。还有一些故障是有多种因素耦合而形成，其传递路径复杂、持续时间短，常常难以检测。

（3） 不确定性：数据的采集、输送、存储过程中常常混杂有大量噪声，这使得工业系统的故障常常具有不确定性。

2.2 深度学习故障诊断的障碍

（1）在解决复杂工业系统故障的过程中，特征提取和故障机理映射起着重要作用。故障机理是通过理论或大量实验分析，得出了反映设备故障状态信号与设备系统参数之间关联映射规律的结果。然而，由于获取完整的故障数据样本往往是不切实际的，因此如何将深度学习与现有的故障机理相结合，解决复杂工业系统故障中存在的 “相关性” 问题，以实现有效的系统运行状态特征提取，仍然是一个具有挑战性的问题，并且目前还没有明显的突破性进展[4,28-30]。

（2）复杂性故障诊断. 故障诊断方法研究中提出了许多有效的 “望闻问测” 诊断手段,但针对早期故障、微弱故障、复合故障、系统故障等的诊断方法还存在不足,可靠的诊断方法有限,系统运行过程中不可避免地产生损伤和出现早期故障,其具有潜在性和动态响应微弱性. 复合故障和系统故障由于多因素耦合和传递路径复杂,往往导致单一信号处理方法难以有效溯源故障成因,而目前针对此复杂性故障有效的解决方案就是增加传感器力求通过增加监测手段实现该类复杂性故障的检测与诊断[4,28-30] .

（3）工业故障诊断中的小样本问题. 海量的正常运行数据与小样本的故障状态数据 是工业大数据的一个典型特点,而深度学习又需要 大量的样本进行训练,二者之间的矛盾似乎不可调和。,如何设计出一个适用于多源输入数 据,同时具有较好功能的特征提取模型来解决复杂工 业系统 “大数据” 难题,实现复杂工业系统故障诊断 也是其中的一个挑战。

（4）深度学习的可解释性问题. 深度学习因为是一种黑箱模型，其在进行故障诊断时可解释性往往很差，其泛化能力备受质疑。如何有效的解决基于深度学习的故障诊断的解释性问题时面临的一大挑战。

（5）训练样本多源不统一.虽然工业过程产生了海量的数据，其中大量的数据由于分布不同，不同源但相似数据间的信息不能被有效融合利用。如何构建深度学习方法课以适应协调多源数据，也是一个很大的挑战。

3.结论

本篇文章针对深度学习在故障诊断中的应用做出了简要的介绍。首先介绍了 DBN、SAE、CNN、RNN 几种相关深度学习算法的原理和近几年国内外的一些改进算法相关研究。最后简要介绍了大型复杂工业系统的特性，目前一些存在的挑战和未来研究的方向。

参考文献

[1] 段艳杰， 吕宜生， 张杰， 等. 深度学习在控制领域的研究现状与展望 [J]. 自动化学报， 2016，42(5):643-654.(Duan Y J， Lv Y S， Zhang J， et al. Deep learning for control: The state of the art and prospects[J]. Acta Automatica Sinica， 2016， 42(5): 643-654.)

[2] Dong Yu， Li Deng. Deep learning and its applications to signal and information processing[J]. IEEE Signal Processing Magazine， 2011， 28(1): 145-154.

[3] Haidong Shao， Hongkai Jiang， Xun Zhang， et al. Rolling bearing fault diagnosis using an optimization deep belief network[J]. Measurement Science and Technology， 2015， 26(11): 115002.

[4] 任浩，屈剑锋，柴毅，唐秋，叶欣.深度学习在故障诊断领域中的研究现状与挑战[J]. 控制与决策，2017，32(08):1345-1358.

[5] Haidong Shao， Hongkai Jiang， Xun Zhang， et al. Rolling bearing fault diagnosis using an optimization deep belief network[J]. Measurement Science and Technology， 2015，26(11): 115002.

[6] Wang Xingqing， Li Yanfeng， Ting Rui， et al. Bearing fault diagnosis method based on Hilbert envelope spectr-um and deep belief network[J]. J of Vibroen-gineering， 2015，17(3): 1295-1308.

[7] Zhiqiang Chen， Chuan Li， René-Vinicio Sánchez.Multi-layer neural network with deep belief network forgearbox fault diagnosis[J]. J of Vibroengin-eering， 2015，17(5): 2379-2392.

[8] Chuan Li， René-Vinicio Sánchez， Grover Zurita， et al. Multimodal deep support vector classification with homologous features and its application to gearbox fault diagnosis[J]. Neurocomputing， 2015， 168(C): 119-127.

[9] L. Xue，L. Ningyun，C. Chuang，H. Tianzhen and J. Bin， Attention mechanism based multi-scale feature extraction of bearing fault diagnosis[J]. Journal of Systems Engineering and Electronics， 2023，34(5): pp. 1359-1367.

[10] Yalin Wang, Zhuofu Pan,, et al. A novel deep learning based fault diagnosis approach for chemical process with extended deep belief network[J],ISA Transactions, 2020, 96(457-467)

[11] Wei Y , Weng Z .Research on TE process fault diagnosis method based on DBN and dropout[J].The Canadian Journal of Chemical Engineering, 2020, 98(6).

[12] Wende Tian , Zijian Liu , et al. (PSE)identification of abnormal conditions in high-dimensional chemical process based on feature selection and deep learning[J]. Chinese Journal of Chemical Engineering. 2020,

[13] Martin Langkvist, Lars Karlsson, Amy Loutfi. A review of unsupervised feature learning and deep learn-ing for time-series modeling[J]. Pattern Recognition Letters, 2014, 42(1): 11-24.

[14] 邱立达, 刘天健, 林南, 等. 基于深度学习模型的无线传感器网络数据融合算法 [J]. 传感技术学报, 2014,27(12): 1704-1709.

[15] Demetgul M, Yildiz K, Tashin S, et al. Fault diagnosis on material handling system using feature selection and data mining techniques[J]. Measurement, 2014, 55(9): 15-24

[16] 张磊. 基于改进的堆栈稀疏自编码器的轴承故障诊断方法研究[D].合肥工业大学，2023

[17] Wenjun Sun, Siyu Shao, Rui Zhao, et al. A sparse auto-encoder-based deep neural network approach for induction motor faults classification[J]. Measurement, 2016, 89: 171-178.

[18]陈里里,司吉兵,董绍江.堆栈稀疏自编码器的风力机锥齿轮故障诊断[J].机械设计与制造,2021(03):161-164.

[19] Peng H-K, Marculescu R. Multi-scale compositio-nality:Identifying the compositional structures of social dynamics using deep learning[J].

PLOS one, 2015, 10(4):e0118309.
[20]张佳鑫,张淼,戴一阳等.面向实际化工过程故障诊断的强化深度卷积神经网络模型构建与应用[J/OL].化工进展,2024,1-14.
[21] ZhiQiang Chen, Chuan Li, Rene-Vinicio Sanchez. Gearbox fault identification and classification with convolutional neural networks[J]. Shock and Vibration, 2015, 390134
[22]闫绘宇,张超.基于 Transformer 和卷积神经网络的齿轮故障诊断方法[J/OL].机电工程,2024,(1-11)
[23] Talebi H A, Khorasani K, Tafazoli S, et al. A recurrent neural-network-based sensor and actuator fault detection and isolation for nonlinear systems with application to the satellite's attitude control subsyste-m[J]. IEEE Transon Neural Network, 2009, 20(1): 45-60.
[24] Bilin Shao, Xiaoli Hu, et al. A Multichannel LSTM-CNN Method for Fault Diagnosis of Chemical Process[J]. Mathematical Problems in Engineering, 2019.
[25] M. Mahmoud, M. Kasem, A. Abdallah and H. S. Kang, AE-LSTM: Autoencoder with LSTM-Based Intrusion Detection in IoT[J], International Telecommunications Conference, 2022,(1-6)
[26] Shaodong Zheng, Jinsong Zhao. A new unsupervised data mining method based on the stacked autoencoder for chemical process fault diagnosis[J], Computers & Chemical Engineering, 2020, 135
[27] Matthew J Daigle, Indranil Roychoudhury, Gautam Biswas, et al. A comprehensive diagnosis methodology for complex hybrid systems: A case study on spacecraft power distribution systems[J]. IEEE Trans on Systems, Man, and Cybernetics-Part A: Systems and Humans, 2010, 40(5): 917-931.
[28] Baoping Cai, Hanlin Liu, Min Xie. A real-time fault diagnosis methodology of complex systems using object-oriented Bayesian networks[J]. Mechanical CSystems and Signal Processing, 2016, 80: 31-44.
[29] Li Deng. A tutorial survey of architectures, algorithms, and applications for deep learning[J]. Apsipa Trans on Signal & Information Processing, 2014, 3: e2.
[30] Heshan Fernando, Brian Surgenor. An unsupervised artificial neural network versus a rule-based approach for fault detection and identification in an automated assembly machine[J]. Robotics and Computer-Integrated Manufacturing, 2017, 43: 79-88.